


# 予測と観測の統合による 人物動態把握手法の開発

東京大学大学院 博士論文 中西 航 (2014)

20140614 理論談話会  
社会基盤学専攻 M2 伊藤 篤志


## 伊藤の研究

離散選択モデルによる車両挙動解明




## 必要なデータ

上方からの視点の車両軌跡



## 手元にあるデータ



斜め方向視点からの車両軌跡



射影変換

車両軌跡データを射影変換する必要あり

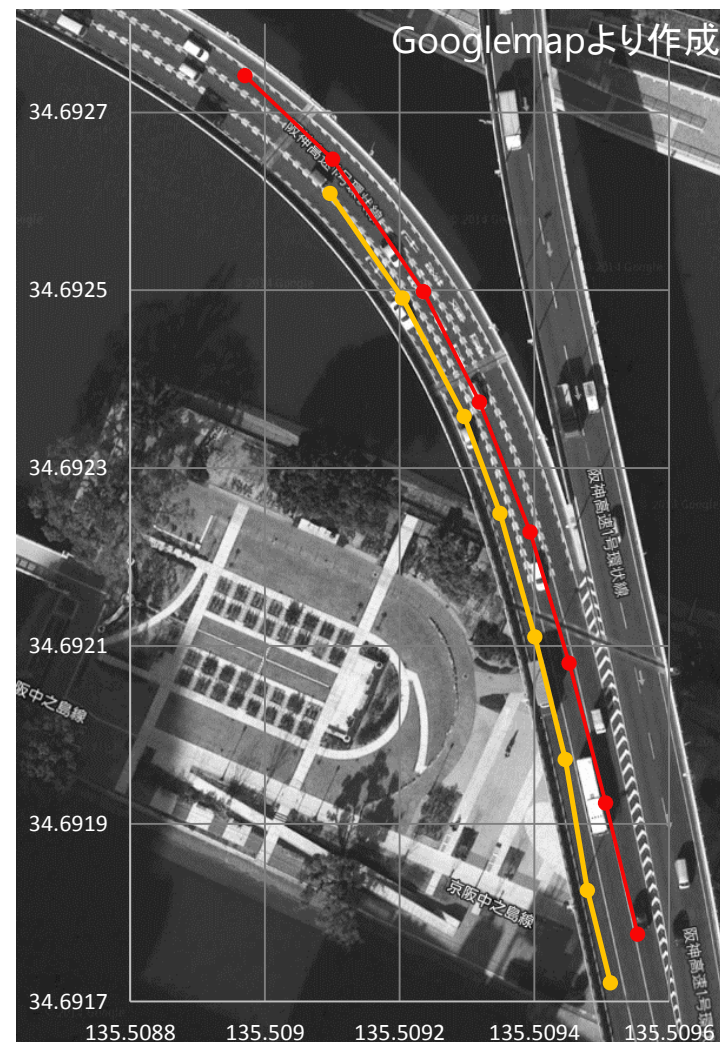
## 射影変換の結果



射影変換

- 実際の車両軌跡
- 射影変換されたデータ

→射影変換によって必要なデータの精度が得られたとは言い難い



データ同化により, モデルが精緻化するのでは?

## 離散選択モデルによる歩行者挙動モデル化



予測シミュレーションとしての歩行者挙動モデル

各時刻における観測情報に基づく動画像処理手法

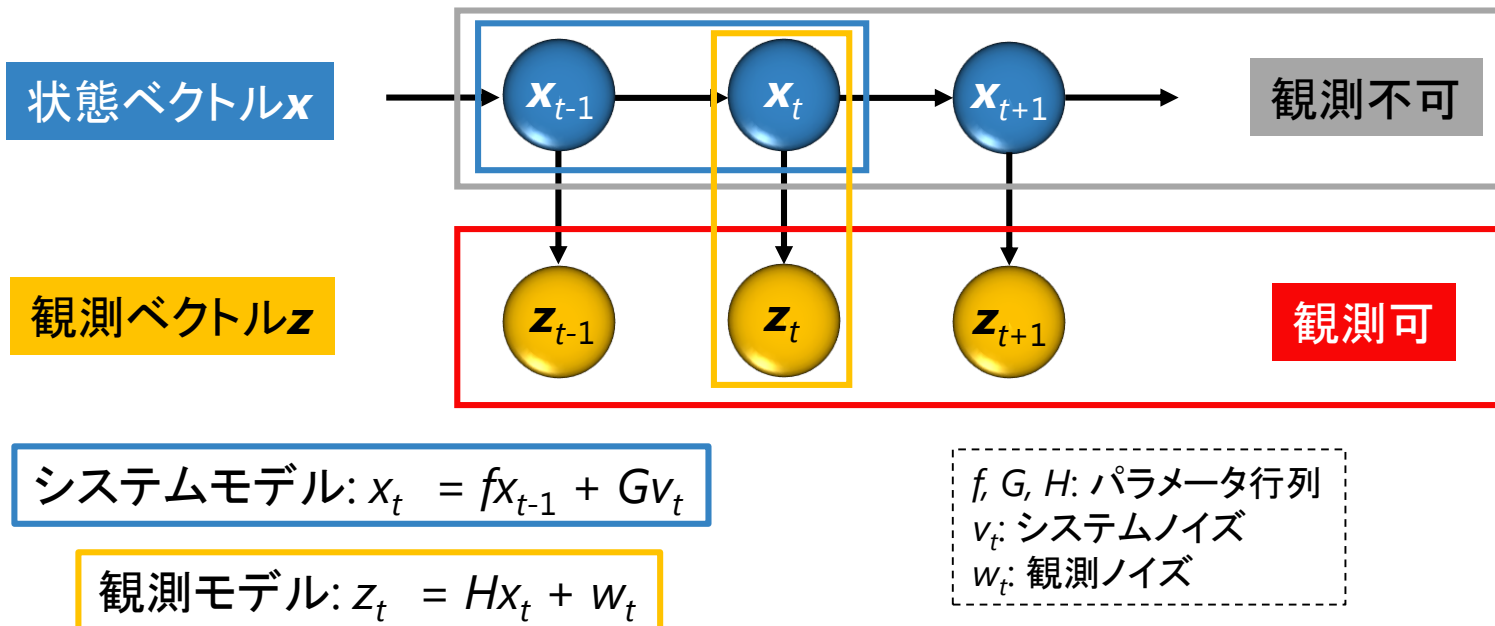
統合

手法	分野	その他の研究分野	人物挙動把握
その他の手法		予測モデルや観測データに不確実性 →決定的なモデルが開発途上	
予測モデルと観測データの統合	真値と仮定できるモデルが存在 (気象や自然科学の分野)	簡易なモデルが多い  時間推移を分布として計算する研究存在せず	


# 一般状態空間モデル

6

理論



本研究



状態ベクトル  $x$


$$x_t = (x_t, y_t, z_t, w_t, h_t, d_t)$$

観測ベクトル  $z$

$i, j$ : 画素の座標  $(i, j)$

$$z_{ij} = (X_{ij}, Y_{ij}, Z_{ij}, r_{ij}, g_{ij}, b_{ij})$$

物理数値シミュレーションモデルと実際の観測を確率的に統合する手法



→ 予測誤差, 観測誤差を修正

データ同化

**非逐次型:**

全てのデータを得た後に, 一括でデータをモデルに統合

**逐次型:**

データを得るたびにモデルに統合

→ 時間変化するシステムに対応可能

事前分布とデータから, 事後分布を導出するための定理

$$p(x_t/z_{1:t}) = \frac{p(z_t/x_t)p(x_t/z_{1:t-1})}{\int p(z_t/x_t)p(x_t/z_{1:t-1})dx_t} = \frac{p(z_t/x_t)p(x_t/z_{1:t-1})}{p(z_t/z_{1:t-1})}$$

逐次型データ同化の基本的な解き型

事後分布(時刻 $t$ ) 観測モデル

$$p(\mathbf{x}_t | \mathbf{z}_{1:t}) \propto p(\mathbf{z}_t | \mathbf{x}_t) \times p(\mathbf{x}_t | \mathbf{z}_{1:t-1})$$


$$= p(\mathbf{z}_t | \mathbf{x}_t) \times \int p(\mathbf{x}_t | \mathbf{x}_{t-1}) \times p(\mathbf{x}_{t-1} | \mathbf{z}_{1:t-1}) d\mathbf{x}_{t-1}$$

事前分布

事後分布(時刻 $t-1$ )

システムモデル

事後分布(時刻 $t-1$ ) 事後分布(時刻 $t$ )





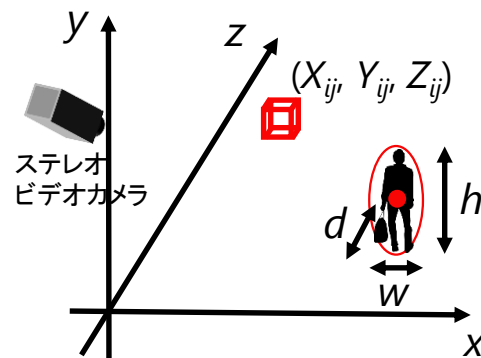
$$p(\mathbf{x}_t | \mathbf{z}_{1:t}) \propto p(\mathbf{z}_t | \mathbf{x}_t) \times \int p(\mathbf{x}_t | \mathbf{x}_{t-1}) \times p(\mathbf{x}_{t-1} | \mathbf{z}_{1:t-1}) d\mathbf{x}_{t-1}$$

~~※~~ 推定すべき状態ベクトル  $\mathbf{x}_t$  の定義

$$\mathbf{x}_t = (x_t, y_t, z_t, w_t, h_t, d_t)$$

~~※~~ 計測可能な観測ベクトル  $\mathbf{z}_t$  の定義


$$\mathbf{z}_{ij} = (X_{ij}, Y_{ij}, Z_{ij}, r_{ij}, g_{ij}, b_{ij})$$



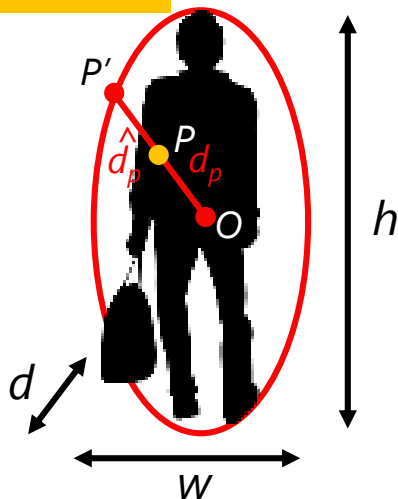
3. 観測モデル  $p(\mathbf{z}_t | \mathbf{x}_t)$  のモデル化

4. システムモデル  $p(\mathbf{x}_t | \mathbf{x}_{t-1})$  のモデル化

5. 初期分布  $p(\mathbf{x}_0)$  のモデル化



## 観測モデル $z$



$P$ : 画素  $ij$  が捉えている点  
 $P = (X_{ij}, Y_{ij}, Z_{ij})$

色情報 と 距離情報 モデルの積

$$p(z_t | x_t) = p(z_t^{color} | x_t) \times p(z_t^{range} | x_t)$$

カラーヒストグラムの類似度  $p_{color}(z_t^{color} | x_t) = \prod_{r,g,b} \sum_m^{255} \sqrt{d_{t,m} d_{t-1,m}}$

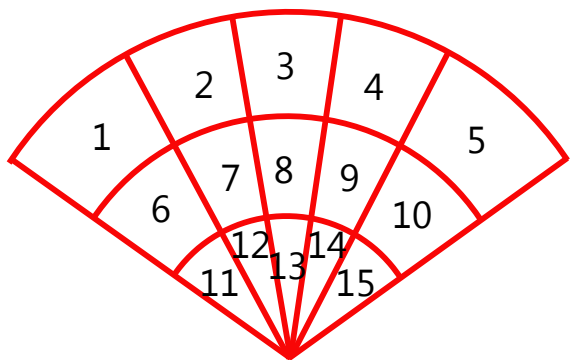
$d_{t,m}$ : ヒストグラム  $d_i$  における画素値  $m$  の相対頻度

形状の類似度

$$p_{range}(z_t^{range} | x_t) = 1 - \frac{1}{l} \sum_p \left( d_p - \hat{d}_p \right)^2$$

$l$ : 対象となる画素数

## システムモデル $x$



多項ロジットモデル

$$V_i = U_{i,v} + U_{i,dir} + U_{i,flow} + U_{i,int} + U_{i,avoid} + U_{i,leader}$$

- $U_{i,v}$ : 速度変更
- $U_{i,dir}$ : 進行方向維持
- $U_{i,flow}$ : 周辺歩行者への同調
- $U_{i,int}$ : 付近の歩行者との衝突回避
- $U_{i,avoid}$ : 前方歩行者の回避
- $U_{i,leader}$ : 前方歩行者の追従

$$\begin{aligned} \text{事後分布(時刻1)} \quad p(\mathbf{x}_1 | \mathbf{z}_{0:1}) &\propto \text{観測モデル} \quad p(\mathbf{z}_1 | \mathbf{x}_1) \times \text{事前分布} \quad p(\mathbf{x}_1 | \mathbf{z}_0) \\ &= p(\mathbf{z}_1 | \mathbf{x}_1) \times \int \text{事後分布(時刻0)} \quad p(\mathbf{x}_0 | \mathbf{z}_0) \times \text{システムモデル} \quad p(\mathbf{x}_1 | \mathbf{x}_0) d\mathbf{x}_{t-1} \end{aligned}$$

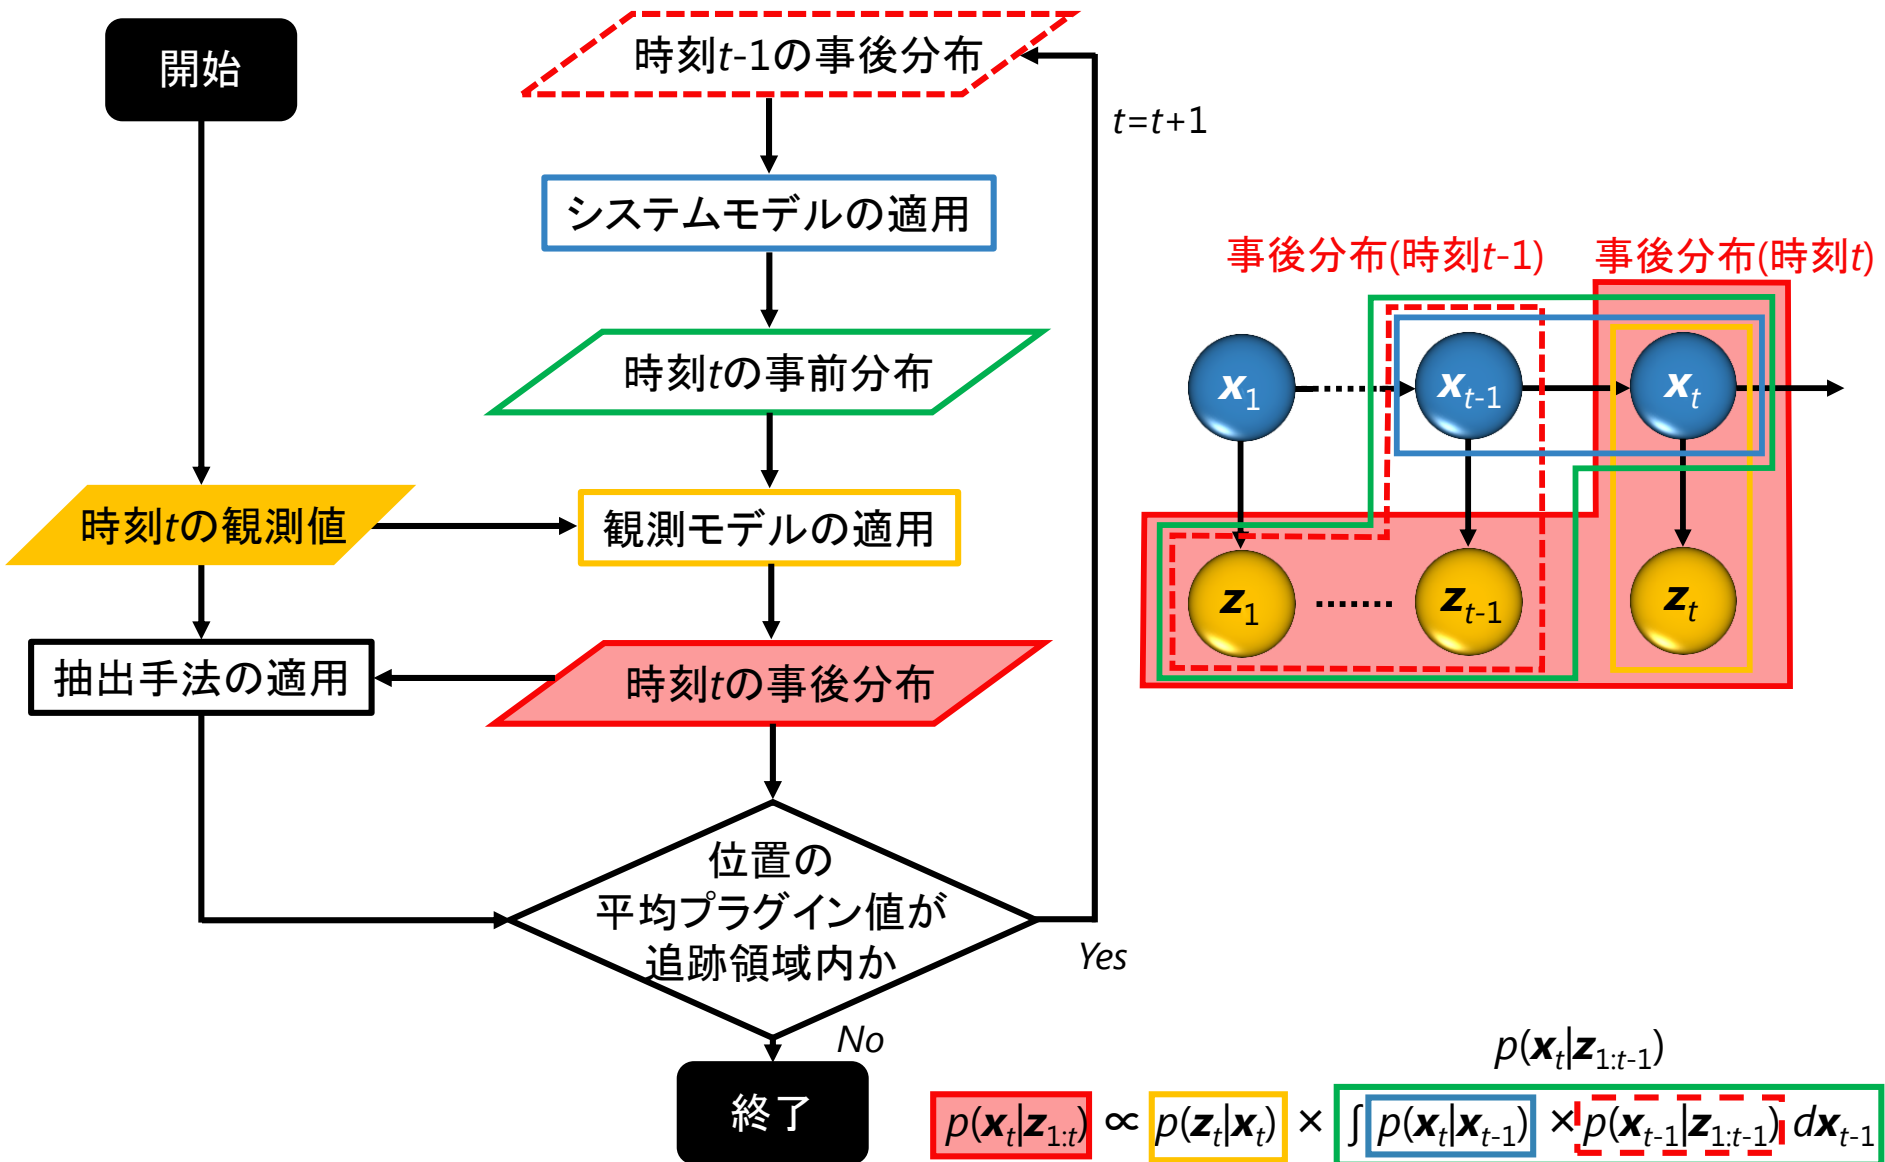
事後分布  $p(\mathbf{x}_0 | \mathbf{z}_0)$  を得るために, 初期分布  $p(\mathbf{x}_0)$  と観測モデル  $p(\mathbf{z}_0 | \mathbf{x}_0)$  を与える

$$p(\mathbf{x}_0 | \mathbf{z}_0) \propto p(\mathbf{z}_0 | \mathbf{x}_0) \times p(\mathbf{x}_0)$$

$$p(\mathbf{z}_0 | \mathbf{x}_0) = p_{color}(\mathbf{z}_0 | \mathbf{x}_0) \times p_{range}(\mathbf{z}_0 | \mathbf{x}_0)$$

$$p(\mathbf{x}_0) \sim N(\bar{\mathbf{x}}_{(prior)0}, \boldsymbol{\sigma}_{init}^2)$$

$\bar{\mathbf{x}}_{(prior)0}$ : 初期分布  $p(\mathbf{x}_0)$  の期待値  
 $\boldsymbol{\sigma}_{init}$ : 分散, 試行実験から決定



## 自己組織化モデリング

状態ベクトルを次のように拡張  $\hat{x}_t = \begin{pmatrix} x_t \\ \theta \end{pmatrix}$

パラメータ $\theta$ を含む事後分布の推定

$$\begin{aligned} p(\hat{\mathbf{x}}_t | \mathbf{z}_{1:t}) &= p(\mathbf{x}_t, \boldsymbol{\theta}_t | \mathbf{z}_{1:t}) \propto p(\mathbf{z}_t | \mathbf{x}_t, \boldsymbol{\theta}_t) \times p(\mathbf{x}_t, \boldsymbol{\theta}_t | \mathbf{z}_{1:t-1}) \\ &= p(\mathbf{z}_t | \mathbf{x}_t, \boldsymbol{\theta}_t) \times \iint p(\mathbf{x}_t, \boldsymbol{\theta}_t | \mathbf{x}_{t-1}, \boldsymbol{\theta}_{t-1}) \times p(\mathbf{x}_{t-1}, \boldsymbol{\theta}_{t-1} | \mathbf{z}_{1:t-1}) d\mathbf{x}_{t-1} d\boldsymbol{\theta}_{t-1} \\ &= p(\mathbf{z}_t | \hat{\mathbf{x}}_t) \times \int p(\hat{\mathbf{x}}_t | \hat{\mathbf{x}}_{t-1}) \times p(\hat{\mathbf{x}}_{t-1} | \mathbf{z}_{1:t-1}) d\hat{\mathbf{x}}_{t-1} \end{aligned}$$

## 全体尤度

実際の観測ベクトルが時系列に得られる同時確率

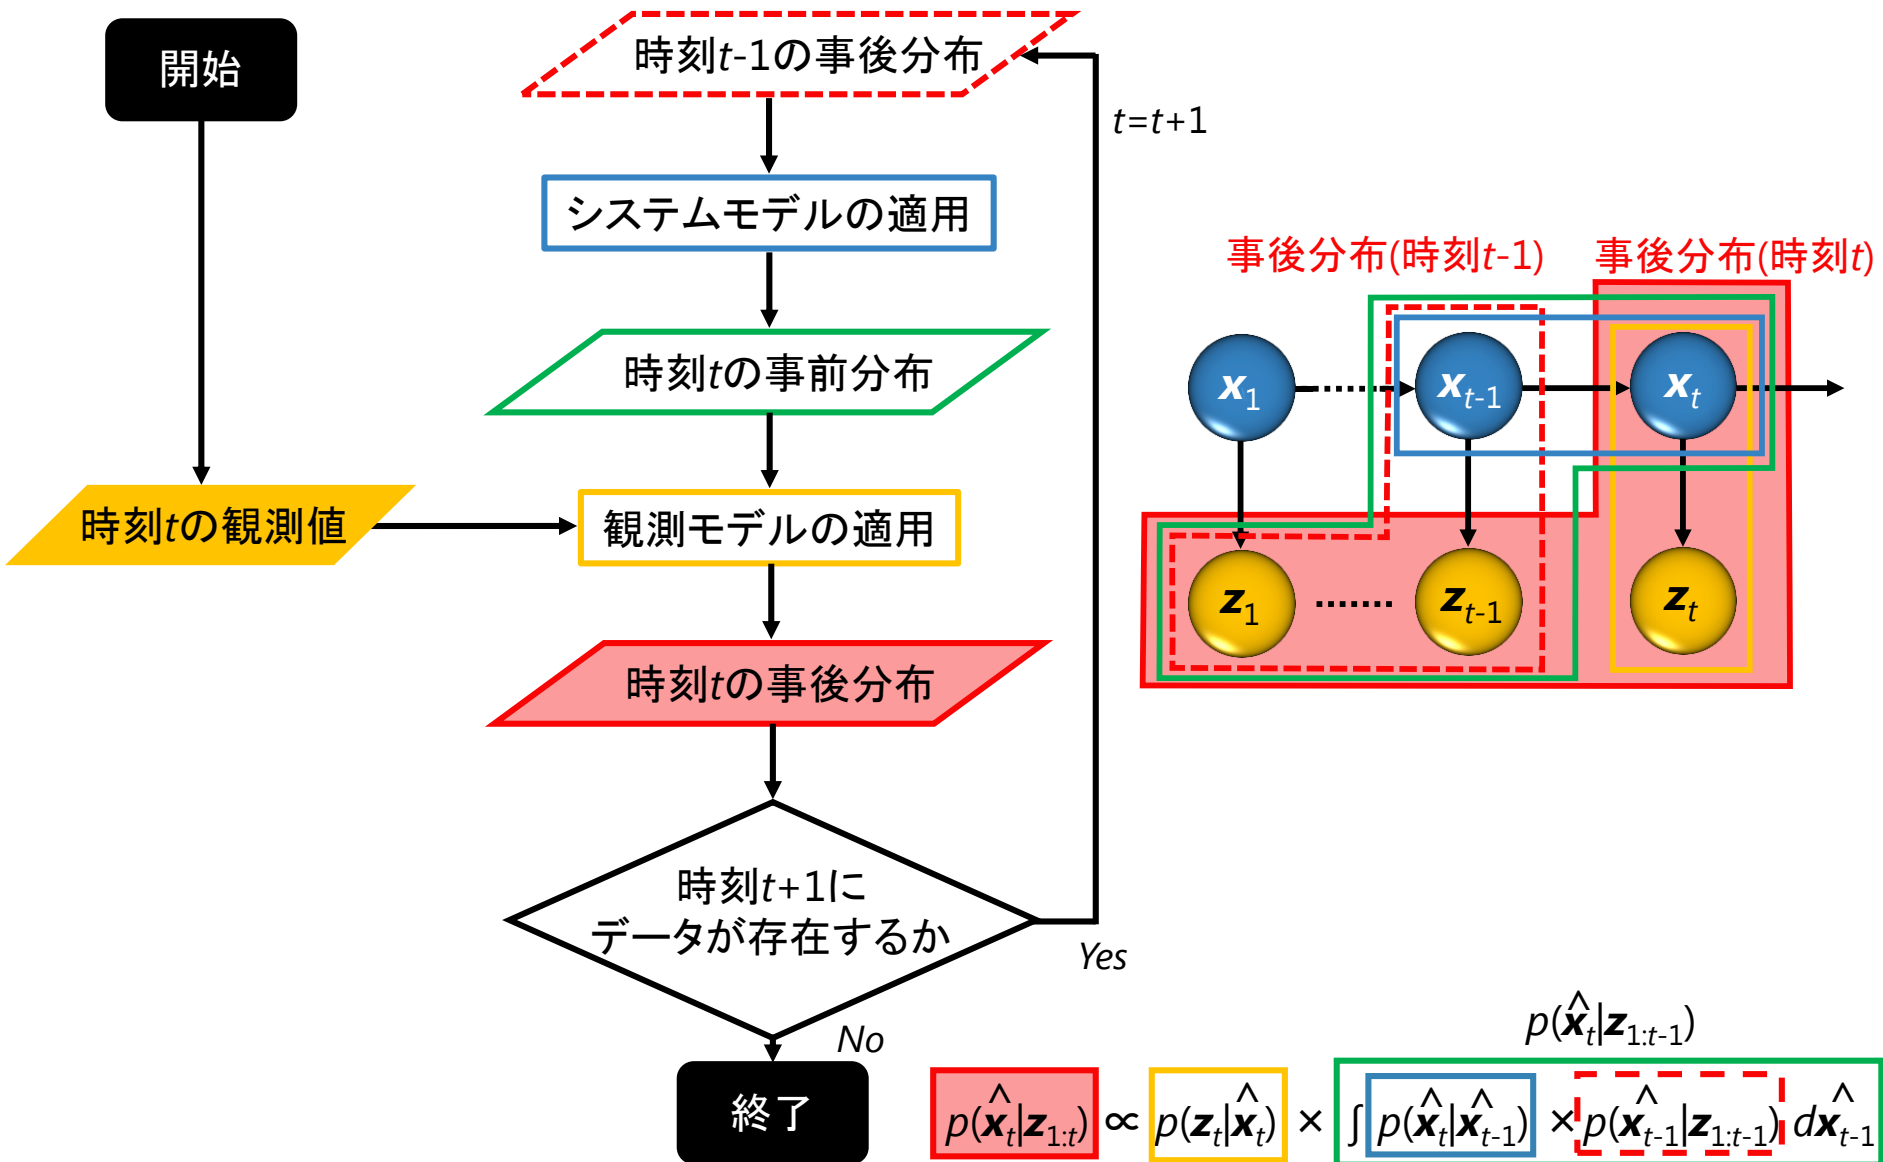
$$p(\mathbf{z}_{1:t}) = \prod_{i=1}^t p(z_i | z_{1:i-1}) = \prod_{i=1}^t \int p(z_i | x_i) p(x_i | z_{1:i-1}) dx_i$$

未知のパラメータ $\theta$ が含まれる場合, 以下の尤度を最大化

$$\log p(\mathbf{z}_{1:t} | \theta) = \sum_{i=1}^t \log p(z_i | z_{1:i-1}, \theta)$$

# 逐次パラメータ推定の流れ

# 14



# 逐次モデル形式変更

全体尤度の式から, 時刻tに関する項に着目する

$$\log p(z_{1:t} | \theta) = \sum_{i=1}^t \log p(z_i | z_{1:i-1}, \theta) = \log p(z_1 | z_{1:0}, \theta) + \cdots + \log p(z_t | z_{1:t-1}, \theta)$$

パーティクルフィルタを用いた近似



$$\left( \log \sum_{i=1}^N w_{t,i} \right) - \log N$$

外れ値検出

尤度比

$$X = \frac{p(z_t | z_{1:t-1}, \theta)}{p(z_{t-1} | z_{1:t-2}, \theta)} \cong \frac{\sum_{i=1}^N w_{t,i} / N}{\sum_{i=1}^N w_{t-1,i} / N} = \frac{\sum_{i=1}^N w_{t,i}}{\sum_{i=1}^N w_{t-1,i}}$$

w: 各粒子の重み  
N: 粒子数

→システムに変化がなければ,  
おおよそ1付近の値をとる

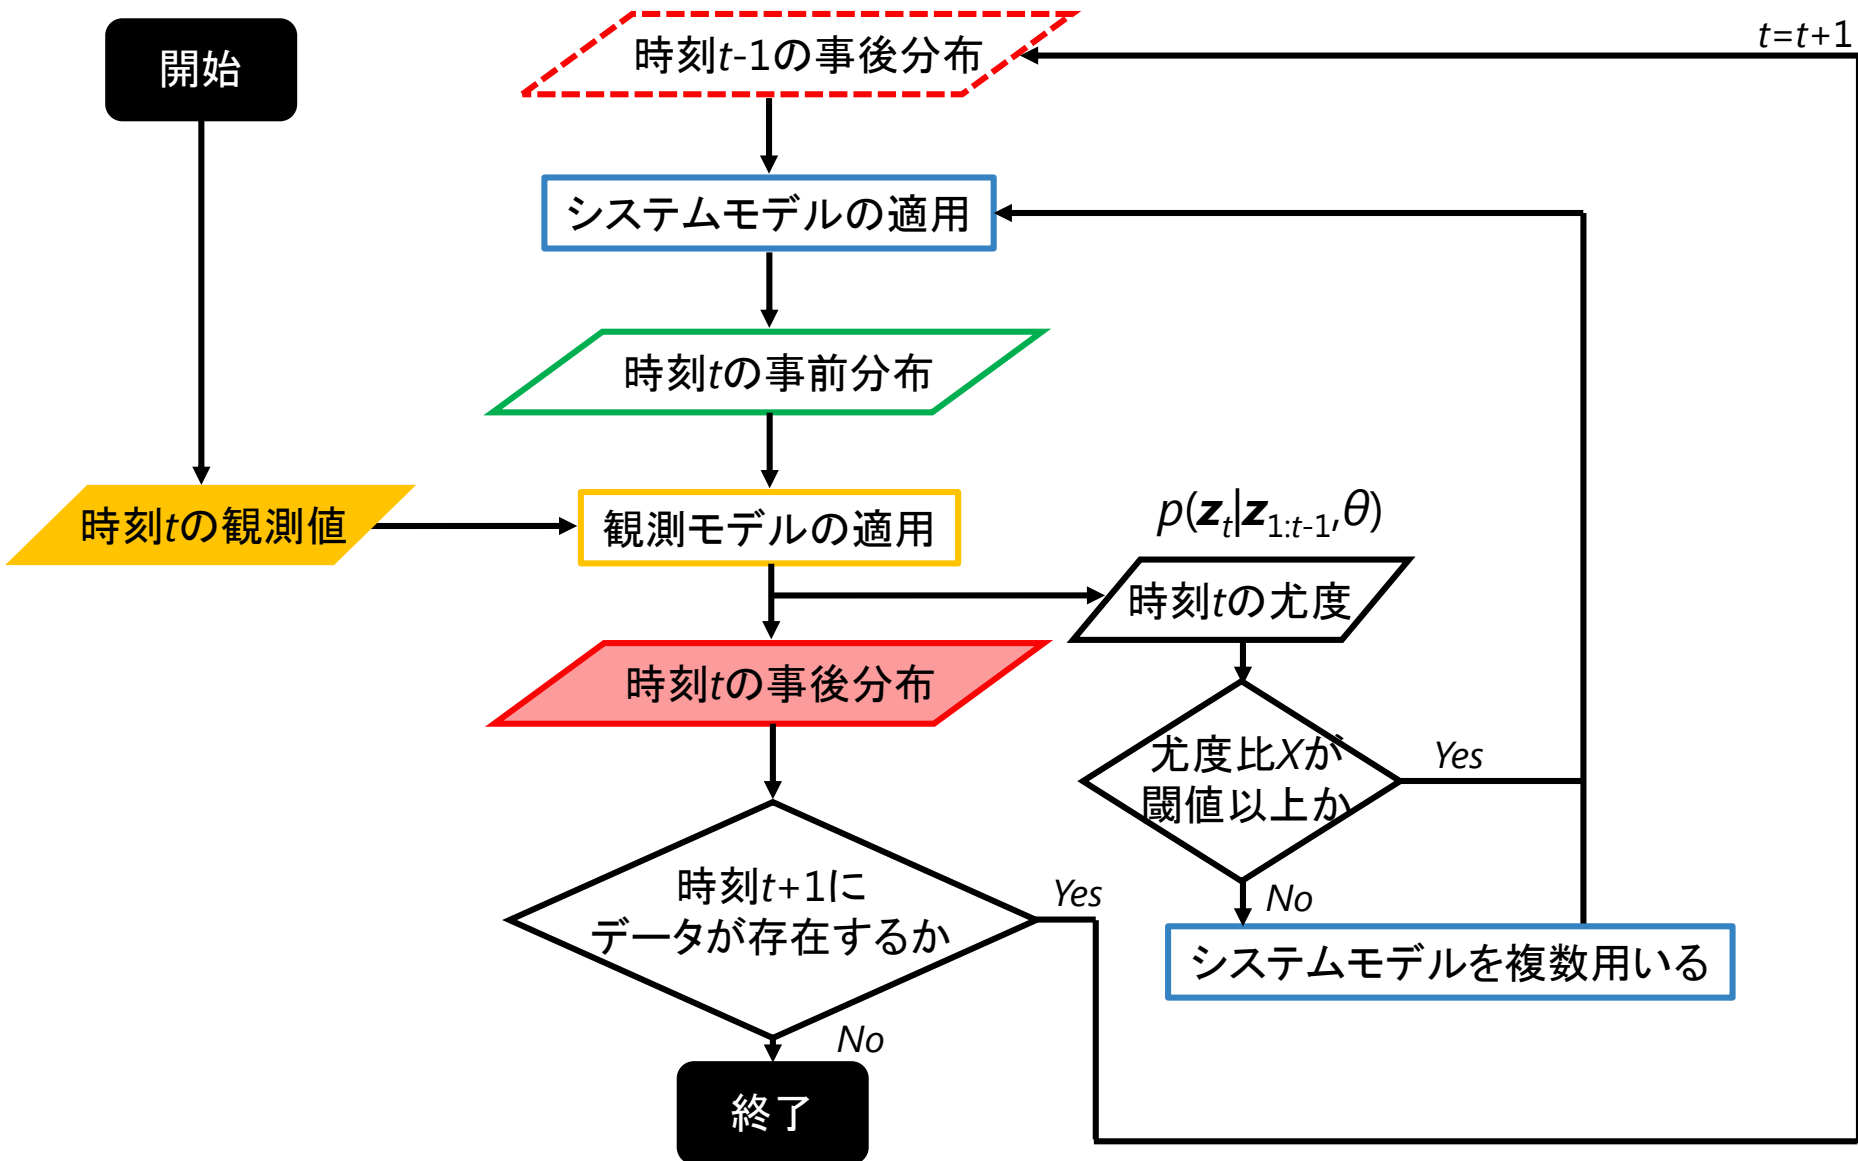
システム自体の変化を検出 時間幅 $t_w$ を設定

尤度比

$$X = \frac{p(z_t | z_{1:t-1}, \theta) \cdots p(z_{t-(t_w-1)} | z_{1:t-t_w}, \theta)}{\underbrace{p(z_{t-1} | z_{1:t-2}, \theta) \cdots p(z_{t-t_w} | z_{1:t-(t_w+1)}, \theta)}_{w\text{個}}} \cong \frac{\sum_{i=1}^N w_{t,i}}{\sum_{i=1}^N w_{t-t_w,i}}$$


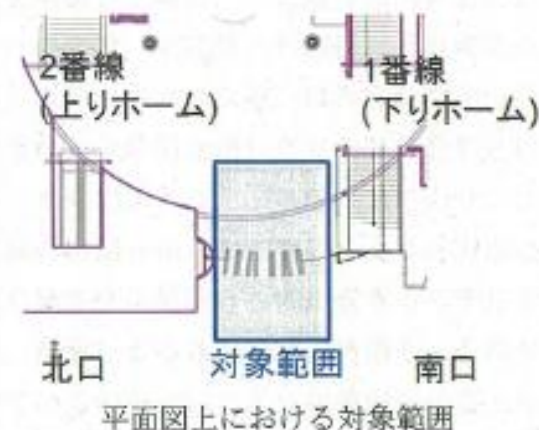
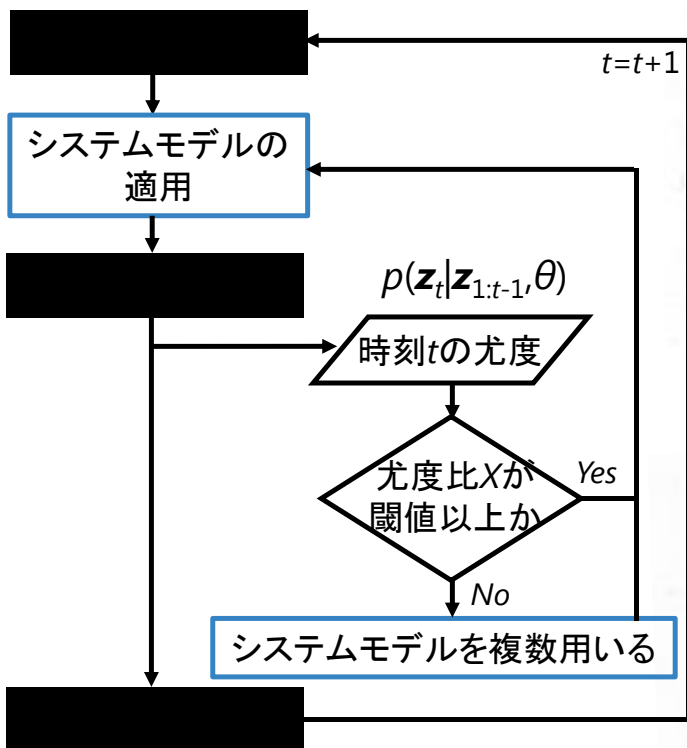
# 逐次モデル形式変更の流れ

# 16





# 逐次モデル変更の結果と考察



逐次変更例

- 尤度が閾値未満モデル変更検討
- 尤度比較によりモデル変更無し
- 尤度が閾値未満モデル変更検討
- 尤度比較によりモデル変更




1. 予測モデルと観測データ統合の枠組みの整理, 人物追跡手法への適用
2. 人物追跡手法を構成するモデルの構築
  - システムモデル
  - 観測モデル
  - 初期分布設定手法
3. 人物挙動の時間・空間による差異を考慮する手法の構築
4. 人物追跡手法の開発と適用結果の分析

# メモ - ベイズの定理

$$\begin{cases} p(A \cap B) = p(A) \times p(B|A) \\ p(A \cap B) = p(B) \times p(A|B) \end{cases}$$

$$\Leftrightarrow \underset{\text{事後分布}}{p(A|B)} = \frac{\overset{\text{事前分布}}{p(A)} \times \overset{\text{尤度}}{p(B|A)}}{p(B)} = \frac{p(A, B)}{p(B)} = \frac{p(A, B)}{\int p(A, B) dA} \quad (\because p(B) = \int p(A, B) dA)$$



# メモ - 言葉の定義

## 状態ベクトル

人物位置, 3次元の楕円体



## 観測ベクトル

色情報, 距離情報



## 観測モデル


ある状態ベクトルとして変数取得時,  
その状態ベクトルから現に得られる観測が  
生起する尤度を表す分布を与えるモデル

## システムモデル

ある時刻における状態ベクトルが与えられたときに,  
次の時刻における状態ベクトルへの遷移確率を与えるモデル

## 初期分布

人物追跡に際した状態ベクトルの初期分布



# メモーフィルタリング

## フィルタリングとは

- ・推定したい状態は必ず観測可能なわけではない
- ・計測の制度には限度

} 状態を推定

## カルマンフィルタ

時系列データに対応, 時間発展を含めた最適化  
(システムの線形成とノイズの正規性を仮定)

## パーティクルフィルタ

事後分布の全域を大域的に近似, 積分を数値的に評価

# メモ - パーティクルフィルタ

$$\begin{aligned}
 \text{事後分布(時刻 } t) \quad & \text{観測モデル} & \text{事前分布} \\
 p(\mathbf{x}_t | \mathbf{z}_{1:t}) & \propto p(\mathbf{z}_t | \mathbf{x}_t) \times p(\mathbf{x}_t | \mathbf{z}_{1:t-1}) \\
 & = p(\mathbf{z}_t | \mathbf{x}_t) \times \int p(\mathbf{x}_t | \mathbf{x}_{t-1}) \times p(\mathbf{x}_{t-1} | \mathbf{z}_{1:t-1}) d\mathbf{x}_{t-1} \\
 & \text{システムモデル}
 \end{aligned}$$

積分の近似計算が必要

$$p(x_{t-1} | z_{1:t-1}) \cong \frac{1}{N} \sum_{i=1}^N \delta(x_t - x_{t|t-1}^{(i)})$$

$x_{t|t-1}^{(i)}$ : 1つ1つのサンプル  
 $N$ : 粒子の数

粒子近似を用いると、  
 積分を和の形で書くことができる

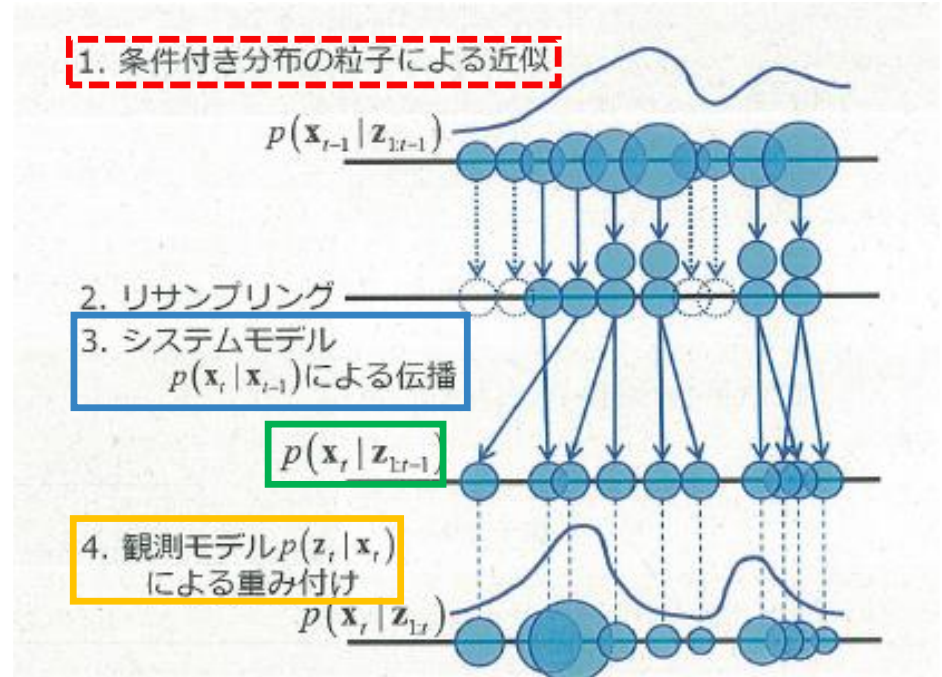


図 3.2 パーティクルフィルタの流れ

# メモ-パーティクルフィルタ

条件付き分布をその分布から多数の実現値で近似表現するもの

